



Janusz Brzeszczyński

Newcastle Business School, Northumbria University, Newcastle-upon-Tyne

Katedra Rynku i Inwestycji Kapitałowych, Instytut Finansów, Wydział Ekonomiczno-Socjologiczny,
Uniwersytet Łódzki, janusz.brzeszczyński@northumbria.ac.uk

Modelowanie i prognozowanie procesów transmisji sygnałów między rynkami akcji. Analiza wpływu zmienności kursowej na giełdach w USA na rynek akcji w Polsce

Streszczenie: Efekty transmisji sygnałów między rynkami finansowymi na świecie, zarówno na poziomie zmienności kursowej, jak i kierunku (znaku) stóp zwrotu, są złożonymi zjawiskami, szczególnie w przypadku wykorzystania danych o wysokiej częstotliwości obserwacji. Artykuł prezentuje modele opisujące te procesy, wybrane kwestie metodologiczne, aplikację empiryczną dla polskiego rynku oraz wskazuje na możliwości wykorzystania omawianych narzędzi do budowy giełdowych strategii inwestycyjnych. Przeprowadzone badanie dla indeksu WIG20 na próbie z lat 2005–2016 dowodzi występowania związku między zmiennością stóp zwrotu indeksu WIG20 a stopami zwrotu indeksów giełdowych z rynku w USA, przy czym najsilniejsza zależność zidentyfikowana została w przypadku indeksu DJIA. Ponadto zaobserwowany został efekt ewolucji zmian wartości estymowanych parametrów w badanych modelach wraz z upływem czasu. Oszacowania parametrów z okresu próby z lat 2005–2016 wykorzystane zostały także w eksperymencie prognostycznym przy użyciu danych z roku 2017 z zastosowaniem dodatkowo kontraktów futures na indeks WIG20.

Słowa kluczowe: rynek akcji, indeksy giełdowe, kontrakty futures na indeksy giełdowe, procesy transmisji informacji między rynkami akcji

JEL: C32, G15, G17

1. Wprowadzenie

Badania dotyczące współzależności między rynkami finansowymi na świecie zajmują ważne miejsce w literaturze oraz posiadają różne interesujące zastosowania praktyczne. Pierwsze analizy w tym obszarze prowadzone były m.in. w pracach K.G. Beckera, J.E. Finnerty'ego i M. Gupty (1990), R.F. Engle'a, T. Ito i W.-L. Lin (1990), Y. Hamao, R. Masulisa i V. Ng (1990), M.A. Kinga i S. Wadhwaniego (1990), T. Ito, R.F. Engle'a i W.-L. Lin (1992), W.-L. Lin, R.F. Engle'a i T. Ito (1994), F. Longina i B. Solnika (2001), R.A. Connolly'ego i F.A. Wanga (2003), G. Bekaerta, C.R. Harveya i A. Ng (2005), B. Gębki i D. Serwy (2007) i innych. Przedmiotem badań w tej dziedzinie jest również pomiar zmian w poziomie oraz intensywności współzależności między giełdami akcji w kontekście zjawisk występujących w okresach turbulencji na rynkach finansowych i związanych z nimi efektów transmisji zmienności kursowej (*financial contagion*) w różnych krajach na świecie (por. m.in. Dornbusch, Park, Claessens, 2000; Forbes, Rigobon, 2002; Karolyi, 2003; Baur, 2012; Beirne, Gieck, 2014; Cho, Hyde, Nguyen, 2015; Dungey i wsp., 2015). Analizy te dotyczyły w szczególności największych kryzysów finansowych, tj. np. kryzysu azjatyckiego w roku 1997 (por. m.in. Gębka, Serwa, 2006) oraz kryzysu GFC (*Global Financial Crisis*) z lat 2007–2008 (por. m.in. Bekaert i wsp., 2014; Bekiros, 2014; Dungey, Gajurel, 2014; Kenourgios, Dimitriou, 2015; Lekonen, 2015; Luchtenberg, Vu, 2015; Lane, Milesi-Ferretti, 2017).

Choć większość publikacji w literaturze na temat współzależności między rynkami finansowymi koncentruje się na rynku akcji, to istnieją również prace wykorzystujące dane dla innych instrumentów finansowych, jak np. obligacji (por. m.in. Blatt, Candelon, Manner, 2015 i in.), walut (por. m.in. Engle, Ito, Lin, 1990; Ito, Engle, Lin, 1992; Melvin Peiers, Melvin, 2003 i in.), a także aktywów niefinansowych, np. metali szlachetnych (por. m.in. Lau i wsp., 2017 i in.).

W nurcie obejmującym powyższe badania szczególną popularność zdobyły modele typu „Meteor Shower”, odwzorowujące procesy transmisji informacji oraz sygnałów między rynkami zlokalizowanymi w różnych regionach geograficznych, oraz modele typu „Heat Wave”, umożliwiające opis tego rodzaju mechanizmów w obrębie tego samego rynku (por. Engle, Ito, Lin, 1990 i in.). Pierwotnie metodologia ta została stworzona do badania zmienności kursowej (*price volatility*), a obecnie znajduje szerokie zastosowanie w modelowaniu i prognozowaniu kierunku ruchu cen instrumentów finansowych. Większość istniejących w literaturze prac empirycznych dotyczy zastosowań dla giełd papierów wartościowych.

Procesy transmisji sygnałów między rynkami akcji, zarówno na poziomie zmienności kursowej, jak i kierunku (znaku) stóp zwrotu, są złożonymi zjawiskami, co wynika z wykorzystania w tego rodzaju modelach danych o wysokiej częstotliwości obserwacji, tj. dziennych lub o częstotliwości wyższej niż dzienna (*intra-daily*). Wiąże się z tym także wiele różnych zagadnień o charakterze metodologicznym.

W przypadku badań prowadzonych na danych pochodzących z polskiego rynku akcji jedną z pierwszych prac w tym obszarze jest artykuł J. Brzeszczyńskiego i A. Welfego (2007), w którym zaprezentowane zostały wyniki empiryczne wskazujące na występowanie zależności między stopami zwrotu indeksu WIG a stopami zwrotu innych indeksów z giełd na świecie. Najsilniejszy związek został jednak zidentyfikowany w przypadku stóp zwrotu indeksu DJIA z giełdy w Nowym Jorku w dniu poprzednim (a także, w słabszym stopniu, stóp zwrotu indeksu NASDAQ z poprzedniego dnia). Procesy transmisji zmienności kursów giełdowych z rynków międzynarodowych na polski rynek akcji w badanej próbie statystycznej, obejmującej lata 1998–2002, zdominowane były więc przez sygnały z giełd w USA.

Celem artykułu jest opis modeli transmisji sygnałów na przykładzie rynków akcji, omówienie wybranych kwestii metodologicznych, empiryczna aplikacja dla danych z polskiego rynku akcji (dla przypadku, w którym rynkami sygnalizującymi są giełdy w USA), ze szczególnym uwzględnieniem danych dotyczących kontraktów futures na indeks WIG20, oraz wskazanie na możliwości dalszego wykorzystania tego typu narzędzi ekonometrycznych do budowy strategii inwestycyjnych na międzynarodowych giełdach papierów wartościowych.

2. Modelowanie procesów transmisji sygnałów między rynkami akcji na świecie

W najprostszym ujęciu modele opisujące mechanizmy transmisji sygnałów w postaci dziennych stóp zwrotu między dwoma rynkami akcji na świecie, które umiejscowione są w określonych sekwencjach czasowych wyznaczanych przez ich położenie geograficzne, mają następującą ogólną postać:

$$r_t^{ro} = \alpha + \beta \cdot r_{t-1}^{rs} + \zeta_t, \quad (1)$$

gdzie:

r_t^{ro} – dzienna stopa zwrotu indeksu giełdowego z rynku odbierającego sygnał (ro),

r_t^{rs} – dzienna stopa zwrotu indeksu giełdowego z rynku sygnalizującego (rs),

α oraz β – szacowane parametry,

ζ_t – składnik losowy.

Należy pamiętać, iż ze względu na występujące w rzeczywistości opóźnienia czasowe zmienne r_t^{rs} dla indeksów giełdowych z rynków sygnalizujących w praktyce będą musiały być w większości przypadków opóźnione o jeden okres (lub

więcej), czyli będą posiadały subskrypt $t - 1$ w nazwie zmiennej r_{t-1}^{rs} . Na przykład, jeśli rynkiem sygnalizującym jest giełda w Nowym Jorku, reprezentowana w modelu przez indeks Dow Jones Industrial Average (DJIA), a rynkiem odbierającym sygnał jest giełda w Londynie, reprezentowana przez indeks FTSE 100, to zgodnie z sekwencją czasową, w jakiej zlokalizowane są te dwa centra finansowe, stopa zwrotu indeksu DJIA w modelu indeksu FTSE 100, gdzie zmienną objaśnianą jest r_t^{FTSE} dla dnia t , musi pochodzić z dnia poprzedniego $t - 1$, czyli powinna być zapisana jako r_{t-1}^{DJIA} , ponieważ w dniu t jej wartość nie jest jeszcze znana przed otwarciem rynku w Londynie.

Ze względu na to, że sesje giełdowe trwają na większości rynków zaledwie około 8 godzin, a więc realizowane przez indeksy giełdowe dzienne stopy zwrotu dotyczą tylko takiego okresu (zamiast pełnych 24 godzin), to z punktu widzenia prognozowania wartości zmiennych r_t^{ro} zwykle przedmiotem zainteresowania użytkowników takich modeli jest jedynie okres od otwarcia danego rynku do jego zamknięcia tego samego dnia. Zapis równania (1) należy zatem skorygować przez wprowadzenie bardziej szczegółowej definicji dziennej stopy zwrotu indeksów giełdowych, czyli dla rynku odbierającego sygnał (ro):

$${}_{oz}r_t^{ro} = \frac{p_t^{ro,z} - p_t^{ro,o}}{p_t^{ro,o}}, \quad (2a)$$

gdzie:

$p_t^{ro,z}$ – wartość zamknięcia indeksu giełdowego z rynku odbierającego sygnał (ro) w dniu t ,

$p_t^{ro,o}$ – wartość otwarcia indeksu giełdowego z rynku odbierającego sygnał (ro) w dniu t .

Analogicznie dzienna stopa zwrotu indeksu giełdowego dla rynku sygnalizującego (rs) przyjmuje następującą postać:

$${}_{oz}r_t^{rs} = \frac{p_t^{rs,z} - p_t^{rs,o}}{p_t^{rs,o}}, \quad (2b)$$

gdzie:

$p_t^{rs,z}$ – wartość zamknięcia indeksu giełdowego z rynku sygnalizującego (rs) w dniu t ,

$p_t^{rs,o}$ – wartość otwarcia indeksu giełdowego z rynku sygnalizującego (rs) w dniu t .

Szacunek wartości parametrów omawianych równań, zapisanych w ogólnej postaci za pomocą wzoru (1), odbywa się na podstawie danych o wysokiej częstotliwości obserwacji, co powoduje, że niemal zawsze występuje w nich problem heteroskedastyczności składnika losowego. Dlatego też w praktyce w procesie es-

tymacji ekonometrycznych konieczne jest zastosowanie metodologii ARCH (*Autoregressive Conditional Heteroscedasticity*), a więc w konsekwencji model (1), dla specyfikacji np. GARCH(1,1), przyjmie postać¹:

$${}^{oz}r_t^{ro} = \alpha + \beta \cdot {}^{oz}r_{t-1}^{rs} + \xi_t, \quad (3a)$$

$$\xi_t = \mathcal{G}_t \sqrt{h_t}, \quad (3b)$$

$$h_t = \gamma_0 + \sum_{s=1}^S \gamma_s \xi_{t-s}^2 + \sum_{q=1}^Q \varphi_q h_{t-q}, \quad (3c)$$

gdzie $\mathcal{G}_t : \text{IID}(0,1)$, $\xi_t : \text{IID}(0, \sigma_\xi^2)$ oraz $S > 0$, $Q \geq 0$, $\gamma_0 > 0$, $\gamma_s \geq 0$, $\varphi_q \geq 0$ (zob. Engle, 1982; Bollerslev, 1986).

Głównym przedmiotem zainteresowania w kontekście badań współzależności między rynkami akcji na świecie jest oszacowanie parametru β w równaniu (3a), którego wartości w odpowiednich modelach pozwalają na analizę natury procesów transmisji sygnałów między giełdami².

Ważnym zagadnieniem jest również stabilność oszacowania parametru β w czasie oraz wiedza na temat możliwej ewolucji jego wielkości, w tym nawet zmiany znaku, co będzie przedmiotem rozważań w kolejnych częściach tego artykułu.

Dalsze rozwinięcia omawianej metodologii dotyczą m.in. włączenia informacji o charakterze makroekonomicznym. W tym nurcie literatury podejście tego rodzaju zaproponowali np. R. A. Connolly i F. A. Wang (2003) – w postaci modelu, który słu-

¹ Specyfikacja GARCH(1,1) jest empirycznie najbardziej popularna w porównaniu z innymi alternatywnymi postaciami modeli klasy ARCH, posiadającymi wyższe stopnie opóźnień lub np. inne formy funkcyjne, czego dowodzą różne badania istniejące w literaturze. Na przykład, w pracy S. Armitage'a i J. Brzeszczyńskiego (2011), w której porównanych zostało wiele modeli typu ARCH, specyfikacja GARCH była wariantem najlepiej dopasowującym się do danych historycznych, a w szczególności występowała zdecydowana dominacja prostej specyfikacji GARCH(1,1), która była przeważającym wariantem aż w 77% przypadków wśród wszystkich badanych modeli.

² Zjawiska transmisji sygnałów między rynkami akcji na świecie można także odwzorowywać za pomocą modeli ze zmiennymi w czasie parametrami, których przykładem jest np. model FIT (*Foreign Information Transmission Model*), będący modelem regresji, w którym dla specyfikacji z równania (3a) dopuszcza się zmienność parametrów α_t oraz β_t każdego dnia t (zob. Ibrahim, Brzeszczyński, 2009; 2014). Opis ewolucji w czasie parametrów α_t oraz β_t w modelu FIT odbywa się za pomocą dodatkowych dwóch równań wykorzystujących trzecią zmienną, ${}^{oc}r_t^{rp}$, zdefiniowaną jako dzienna stopa zwrotu indeksu giełdowego z rynku pośredniego (rp), który w sekwencji czasowej występuje między rynkiem odbierającym sygnał (ro), reprezentowanym przez stopę zwrotu ${}^{oc}r_t^{ro}$, a głównym rynkiem sygnalizującym (rs), reprezentowanym przez stopę zwrotu ${}^{oc}r_t^{rs}$. Zmienność wartości parametrów α_t oraz β_t w modelu FIT odwzorowuje schemat autoregresyjny.

ży do opisu procesów transmisji sygnałów między rynkami akcji na świecie oraz dodatkowo pozwala na uwzględnienie wpływu informacji o ogłaszanych wielkościach najważniejszych kategorii makroekonomicznych, pochodzących zarówno z analizowanego rynku, jak i z innych (sygnalizujących) rynków zagranicznych³.

Kolejną zmienną, jaka może być dodatkowo wykorzystana w omawianych modelach, jest wolumen obrotów giełdowych, który w kontekście modeli transmisji sygnałów interpretowany jest jako miara poziomu aktywności danego rynku⁴. Informacja taka może zostać zastosowana do dalszej rozbudowy odpowiednich modeli, np. przez dezagregację danych na temat wolumenu pod względem intensywności obrotu akcjami każdego dnia (zob. m.in. Sheng, Brzeszczyński, Ibrahim, 2017).

3. Strategie inwestycyjne na rynkach akcji oparte na modelach transmisji sygnałów

Modele transmisji sygnałów między rynkami akcji na świecie mogą służyć jako podstawa do budowy strategii inwestycyjnych. Prognozy zmiennych w postaci dziennych stóp zwrotu indeksów giełdowych ${}^{\sigma}r_t^{ro}$, oparte na informacjach o zrealizowanych wartościach dziennych stóp zwrotu indeksów z rynków sygnalizujących ${}^{\sigma}r_{t-1}^{rs}$, mogą być bowiem wykorzystane w naturalny i bezpośredni sposób w procesach decyzyjnych przez inwestorów giełdowych.

W praktyce kluczowym zagadnieniem przy konstrukcji tego rodzaju systemów jest wykonalność transakcji na modelowanym i prognozowanym instrumencie. W przypadku indeksów giełdowych może to okazać się w rzeczywistości dość trudne, gdyż strategia tego typu wymagałaby zakupu przez inwestora wszystkich składowych akcji z indeksu oraz ich sprzedaży w bardzo krótkich okresach inwestycyjnych, tj. jednego dnia (od rozpoczęcia sesji giełdowej rano do jej zakończenia w godzinach popołudniowych tego samego dnia). Dlatego też zwykle transakcje

³ Dane makroekonomiczne, tj. dynamika wzrostu PKB i inne, wykorzystywane są w badaniach dotyczących omawianych modeli również do podziału prób statystycznych na podokresy, np. wzrostu gospodarczego i recesji, oraz do analizy procesów transmisji sygnałów między rynkami w tak wyszczególnionych podpróbach, a także do kwantyfikacji związków między koniunkturą gospodarczą i koniunkturą giełdową (dla Polski wyniki takich badań prezentuje np. praca J. Brzeszczyńskiego, J. Gajdki i T. Schabka, 2009).

⁴ Wolumen obrotów jest zmienną, której zastosowanie pozwala z większą precyzją opisywać procesy kształtowania się kursów instrumentów finansowych, a także diagnozować motywy transakcji dokonywanych przez inwestorów (zob. m.in. Campbell, Grossman, Wang, 1993; Gagnon, Karolyi, 2003; 2006; 2009; Gębka, 2012 oraz Gębka, Serwa, 2015). Zrozumienie kształtowania się dynamiki wolumenu jest również przedmiotem niezależnych analiz – zob. np. dla wolumenu obrotów na rynku walutowym badanie w artykule J. Brzeszczyńskiego i M. Melvina (2006), a dla rynków akcji i obligacji inne badania w kontekście ich płynności m.in. w artykułach T. Chordii, R. Rolla i A. Subrahmanyamiego (2001) oraz T. Chordii, A. Sarkara i A. Subrahmanyamiego (2005).

takie dokonywane są na kontraktach futures na odpowiednie indeksy giełdowe. Z tego właśnie względu dane dotyczące kontraktów futures są od niedawna wykorzystywane również w badaniach skupiających się na budowie oraz estymacji parametrów modeli opisujących transmisję sygnałów między rynkami (zob. m.in. Yarovaya, Brzeszczyński, Lau, 2016a; 2016b).

Warto dodać, że zastosowanie kontraktów futures ma także jeszcze inną ważną korzyść – w postaci relatywnie niższych kosztów transakcyjnych, jakie z reguły na większości rynków posiadają te instrumenty. Wyniki strategii inwestycyjnych natomiast w oczywisty sposób zawsze zależą od poziomu opłat za wszystkie otwierane i zamykane pozycje. Jest to ważne zagadnienie, które, niestety, często jest pomijane w wielu badaniach. Rezultaty, które nie uwzględniają kosztów transakcyjnych, są jednak mało realistyczne, szczególnie w przypadku takich strategii, jakie są przedmiotem dyskusji w tym artykule, gdzie ze względu na wysoką częstotliwość danych również liczba dokonywanych transakcji jest relatywnie duża.

W praktyce wyniki inwestycji w przypadku realizacji omawianych strategii będą także różnić się, nawet w zależności od typu inwestorów, którzy z natury rzeczy posiadają inne koszty zawierania transakcji ze względu na takie czynniki, jak np. wielkość zlecenia (koszty te są niższe dla dużych inwestorów instytucjonalnych generujących duży obrót oraz wyższe dla małych inwestorów indywidualnych) czy metody zawierania transakcji na rynku.

Pomiar skuteczności prognoz generowanych z modeli regresji, które stosowane są w tego rodzaju strategiach inwestycyjnych, odbywa się głównie na podstawie oceny wartości stóp zwrotu realizowanych w okresie prognozy oraz przez wyznaczenie stóp zwrotu skorygowanych o ryzyko, w tym takich miar, jak wskaźnik Sharpe'a (oraz inne podobne narzędzia, jak np. wskaźnik Treynora lub miara CEQ)⁵.

4. Baza danych oraz próba badawcza

Baza danych wykorzystanych w prezentowanym badaniu obejmuje dzienne wartości otwarcia i zamknięcia indeksów giełdowych z rynków w Polsce i w USA oraz kontraktów futures⁶ z rynku polskiego, na podstawie których wyznaczone zostały ich dzienne stopy zwrotu.

⁵ Ponadto inwestorzy w tym celu mogą wykorzystywać tzw. miary zgodności kierunku, których idea została zaproponowana pierwotnie w pracy M.H. Pesarana i A. Timmermanna (1992) oraz rozwinięta w artykułach M.M. Dacorogny i wsp. (1998) oraz Dacorogny i wsp. (2001) (dla rynku polskiego przykład ich zastosowania w kontekście omawianych modeli znaleźć można np. w artykule Brzeszczyńskiego i Welfego, 2007).

⁶ Notowania kontraktów futures na indeks WIG20 uzyskano z bazy danych Bloomberg w postaci ich rolowanych wartości (kod instrumentu w serwisie Bloomberg: 'KRS1 Index').

Cała próba, w której wykonane zostały estymacje parametrów wszystkich modeli, dotyczy 12 lat od 3.01.2005 do 30.12.2016. Została ona dodatkowo podzielona na dwa równe podokresy o długości 6 lat: 3.01.2005–31.12.2010 oraz 3.01.2011–30.12.2016⁷.

Symulacja prognostyczna w okresie poza próbą (*out-of-sample*) została natomiast przeprowadzona dla roku 2017 w okresie pierwszych 3 miesięcy: od 2.01.2017 do 31.03.2017, podzielonego dodatkowo na 3 horyzonty inwestycyjne: jeden miesiąc (styczeń: 2.01.2017–31.01.2017), dwa miesiące (styczeń – luty: 2.01.2017–28.02.2017) oraz trzy miesiące (styczeń – marzec: 2.01.2017–31.03.2017).

Baza danych wykorzystana w prezentowanym badaniu obejmuje indeks WIG20 z rynku polskiego oraz 6 indeksów z rynku amerykańskiego: Dow Jones Industrial Average (DJIA), Standard and Poor's 500 (S&P 500), Russell 3000, Wilshire 5000, NASDAQ Composite oraz NASDAQ 100. Dodatkowo zawiera ona dane dotyczące dziennych wartości otwarcia i zamknięcia dla kontraktów futures na indeks WIG20, które zastosowane zostały w analizie prognostycznej w okresie poza próbą w roku 2017.

Indeks Dow Jones Industrial Average (DJIA) jest indeksem akcji 30 największych spółek przemysłowych (tzw. *blue chips*) notowanych na giełdzie New York Stock Exchange (NYSE). Mimo że DJIA zawiera tylko 30 składowych, to jest on uznawany za jeden z najważniejszych indeksów z rynku w USA, a jego notowania są podawane we wszystkich finansowych serwisach informacyjnych na świecie. Stanowi on ważny punkt odniesienia dla większości inwestorów giełdowych.

Indeks Standard and Poor's 500 (S&P 500) jest innym popularnym indeksem amerykańskim. Obejmuje on 500 największych akcji z rynku w USA ważonych kapitalizacją giełdową ich spółek.

Kolejne dwa indeksy, Russell 3000 oraz Wilshire 5000, są indeksami szerokiego rynku i zawierają odpowiednio 3000 oraz 5000 największych akcji z rynku amerykańskiego klasyfikowanych według kryterium, jakim jest ich kapitalizacja giełdowa.

Indeksy NASDAQ Composite oraz NASDAQ 100 są indeksami akcji spółek technologicznych z rynku NASDAQ, przy czym NASDAQ Composite składa się z akcji szerokiego rynku, natomiast NASDAQ 100 zawiera tylko 100 największych i najbardziej aktywnych akcji firm niefinansowych.

Źródłem wszystkich danych w badaniu prezentowanym w tym artykule jest serwis Bloomberg.

⁷ Podział całego okresu na dwie równe podpróby został dokonany mechanicznie i podyktowany był zamiarem sprawdzenia różnic w oszacowaniach parametrów w dwóch dłuższych okresach o takim samym zakresie czasowym (dla porównywalności wyników). Bardziej szczegółowa analiza dotycząca występowania efektów ewolucji wartości szacowanych parametrów przeprowadzona została natomiast w dalszej części artykułu w oparciu o podpróby o długości jednego roku.

5. Wyniki badań empirycznych

W badaniu empirycznym wykorzystane zostały modele indeksu WIG20, dla których estymacja parametrów przeprowadzona została na podstawie równań (3a)–(3c). Stopy zwrotu indeksu WIG20 objaśniane były stopami zwrotu kolejnych 6 indeksów amerykańskich.

W skali czasowej CET, zgodnie z którą rejestrowane były wszystkie dane, nowy dzień rozpoczyna się o północy o godzinie 00:00 czasu środkowoeuropejskiego, a więc jeśli stopy zwrotu na rynku ${}^{\text{oz}}r_t^{\text{ro}}$ (czyli w Polsce) dotyczą dnia t , to odpowiednia stopa zwrotu na rynku ${}^{\text{oz}}r_{t-1}^{\text{rs}}$ (czyli w USA) musi być zdefiniowana dla dnia $t - 1$, gdyż giełda amerykańska zamyka się zawsze wieczorem o godz. 22:00 czasu środkowoeuropejskiego poprzedniego dnia w stosunku do otwarcia giełdy w Polsce.

Tabela 1 przedstawia oszacowania parametrów równań dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów Dow Jones Industrial Average (DJIA) oraz Standard and Poor's 500 (S&P 500) z dnia $t - 1$. Wynika z niej, że w obydwóch przypadkach występował silny efekt ARCH, natomiast wartości $\hat{\beta}$ były w każdym przypadku ujemne, jednak statystycznie istotne były tylko w całej próbie oraz w pierwszej podpróbie⁸.

Podobne wyniki ilustruje tabela 2, zawierająca oszacowania parametrów równań dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów Russell 3000 oraz Wilshire 5000 z dnia $t - 1$, gdzie również widać silny efekt ARCH oraz ujemne wartości $\hat{\beta}$, które są jednak statystycznie istotne tylko w całej próbie oraz w pierwszej podpróbie.

Rezultaty w tabeli 3, przedstawiającej oszacowania parametrów równań dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów NASDAQ Composite oraz NASDAQ 100 z dnia $t - 1$, także wskazują na istnienie silnego efektu ARCH, jednak tym razem oszacowanie parametru β nie było statystycznie istotne w żadnym przypadku.

⁸ W całym badaniu prezentowanym w tym artykule wykorzystana została zwykła stopa zwrotu, choć często w podobnych analizach stosuje się także logarytmiczną stopę zwrotu, jednak ze względu na to, że zwykła stopa zwrotu jest bardziej odpowiednia z punktu widzenia obliczeń wyników dla strategii inwestycyjnej, to taka właśnie definicja została konsekwentnie przyjęta dla zmiennych w odpowiednich modelach. Poza tym warto dodać, że wykorzystanie logarytmicznej stopy zwrotu nie prowadzi do znaczących różnic w oszacowaniach w tabelach 1–3. Na przykład w tabeli 1 dla modelu z indeksem DJIA oszacowania parametru $\hat{\beta}$ w całej próbie oraz w obydwóch podpróbach wynoszą odpowiednio: $-0,059656$ **, $-0,115750$ *** oraz $-0,004401$, podczas gdy oszacowania z tego samego modelu z indeksem DJIA, ale z logarytmiczną stopą zwrotu, są na poziomie odpowiednio: $-0,078096$ ***, $-0,111558$ *** oraz $0,007665$ (przy identycznej konkluzji na temat ich istotności statystycznej w całej próbie i w pierwszej podpróbie oraz braku istotności statystycznej w drugiej podpróbie). Takich samych wniosków dostarcza również analiza różnic w oszacowaniach w przypadku estymacji na rocznych podpróbach, które zaprezentowane są w dalszej części artykułu na rysunku 1.

Tabela 1. Oszacowania parametrów równań (3a) oraz (3c) dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów Dow Jones Industrial Average (DJIA) oraz Standard and Poor's 500 (S&P 500) z dnia $t - 1$

Indeks	Zakres próby	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}_0$	$\hat{\gamma}_1$	$\hat{\varphi}_1$
Dow Jones Industrial Average (DJIA)	3.01.2005–30.12.2016	-0,000118 (0,000175)	-0,059656** (0,024382)	$1,83 \times 10^{-6}$ *** ($5,68 \times 10^{-7}$)	0,0722224*** (0,011637)	0,916889*** (0,012746)
	3.01.2005–31.12.2010	0,000119 (0,000291)	-0,115750*** (0,033163)	$2,17 \times 10^{-6}$ ** ($1,02 \times 10^{-6}$)	0,066121*** (0,014307)	0,924158*** (0,015668)
	3.01.2011–30.12.2016	-0,000283 (0,000221)	-0,004401 (0,036362)	$2,69 \times 10^{-6}$ ** ($1,15 \times 10^{-6}$)	0,076220*** (0,020600)	0,898036*** (0,026832)
Standard and Poor's 500 (S&P 500)	3.01.2005–30.12.2016	-0,000124 (0,000175)	-0,052730** (0,024317)	$1,84 \times 10^{-6}$ *** ($5,69 \times 10^{-7}$)	0,0722267*** (0,011662)	0,916782*** (0,012767)
	3.01.2005–31.12.2010	0,000109 (0,000292)	-0,101849*** (0,032473)	$2,20 \times 10^{-6}$ ** ($1,03 \times 10^{-6}$)	0,066241*** (0,014404)	0,923921*** (0,015716)
	3.01.2011–30.12.2016	-0,000284 (0,000221)	-0,003908 (0,036473)	$2,69 \times 10^{-6}$ ** ($1,15 \times 10^{-6}$)	0,076225*** (0,020605)	0,898006*** (0,026872)

Uwagi: (1) W nawiasach podane zostały wartości błędów standardowych. (2) Istotność statystyczna * oznacza oszacowanie istotne statystycznie na poziomie 10%, ** oznacza oszacowanie istotne statystycznie na poziomie 5%, a *** oznacza oszacowanie istotne statystycznie na poziomie 1%.

Źródło: obliczenia własne

Tabela 2. Oszacowania parametrów równań (3a) oraz (3c) dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów Russell 3000 oraz Wilshire 5000 z dnia $t - 1$

Indeks	Zakres próby	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}_0$	$\hat{\gamma}_1$	$\hat{\varphi}_1$
Russell 3000	3.01.2005–30.12.2016	-0,000125 (0,000175)	-0,048462** (0,023318)	$1,85 \times 10^{-6}$ *** ($5,71 \times 10^{-7}$)	0,072398*** (0,011660)	0,916591*** (0,012768)
	3.01.2005–31.12.2010	0,000110 (0,000292)	-0,096410*** (0,030119)	$2,23 \times 10^{-6}$ ** ($1,04 \times 10^{-6}$)	0,066526*** (0,014435)	0,923486*** (0,015786)
	3.01.2011–30.12.2016	-0,000292 (0,000221)	0,009322 (0,036755)	$2,71 \times 10^{-6}$ ** ($1,16 \times 10^{-6}$)	0,076266*** (0,020654)	0,897851*** (0,026998)
Wilshire 5000	3.01.2005–30.12.2016	-0,000120 (0,000175)	-0,053216** (0,022582)	$1,84 \times 10^{-6}$ *** ($5,69 \times 10^{-7}$)	0,072235*** (0,011651)	0,916806*** (0,012766)
	3.01.2005–31.12.2010	0,000121 (0,000292)	-0,099262*** (0,029918)	$2,20 \times 10^{-6}$ ** ($1,03 \times 10^{-6}$)	0,066125*** (0,014383)	0,924043*** (0,015676)
	3.01.2011–30.12.2016	-0,000282 (0,000221)	-0,007484 (0,034072)	$2,68 \times 10^{-6}$ ** ($1,15 \times 10^{-6}$)	0,076158*** (0,020574)	0,898164*** (0,026836)

Uwagi: (1) W nawiasach podane zostały wartości błędów standardowych. (2) Istotność statystyczna * oznacza oszacowanie istotne statystycznie na poziomie 10%, ** oznacza oszacowanie istotne statystycznie na poziomie 5%, a *** oznacza oszacowanie istotne statystycznie na poziomie 1%.

Źródło: obliczenia własne

Tabela 3. Oszacowania parametrów równań (3a) oraz (3c) dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksów NASDAQ Composite oraz NASDAQ 100 z dnia $t - 1$

Indeks	Zakres próby	$\hat{\alpha}$	$\hat{\beta}$	$\hat{\gamma}_0$	$\hat{\gamma}_1$	$\hat{\varphi}_1$
NASDAQ Composite	3.01.2005–30.12.2016	-0,000138 (0,000175)	-0,025321 (0,023330)	$1,85 \times 10^{-6***}$ ($5,69 \times 10^{-7}$)	0,072368*** (0,011699)	0,916632*** (0,012762)
	3.01.2005–31.12.2010	$7,56 \times 10^{-5}$ (0,000293)	-0,028909 (0,033864)	$2,20 \times 10^{-6**}$ ($1,02 \times 10^{-6}$)	0,066044*** (0,014435)	0,924247*** (0,015606)
	3.01.2011–30.12.2016	-0,000279 (0,000220)	-0,018405 (0,032398)	$2,68 \times 10^{-6**}$ ($1,14 \times 10^{-6}$)	0,075990*** (0,020547)	0,898321*** (0,026738)
NASDAQ 100	3.01.2005–30.12.2016	-0,000138 (0,000175)	-0,026483 (0,022759)	$1,85 \times 10^{-6***}$ ($5,68 \times 10^{-7}$)	0,072279*** (0,011693)	0,916750*** (0,012752)
	3.01.2005–31.12.2010	$7,13 \times 10^{-5}$ (0,000293)	-0,020286 (0,032449)	$2,21 \times 10^{-6**}$ ($1,02 \times 10^{-6}$)	0,066068*** (0,014447)	0,924198*** (0,015616)
	3.01.2011–30.12.2016	-0,000276 (0,000220)	-0,028548 (0,032135)	$2,67 \times 10^{-6**}$ ($1,13 \times 10^{-6}$)	0,075795*** (0,020491)	0,898595*** (0,026641)

Uwagi: (1) W nawiasach podane zostały wartości błędów standardowych. (2) Istotność statystyczna * oznacza oszacowanie istotne statystycznie na poziomie 10%, ** oznacza oszacowanie istotne statystycznie na poziomie 5%, a *** oznacza oszacowanie istotne statystycznie na poziomie 1%.

Źródło: obliczenia własne

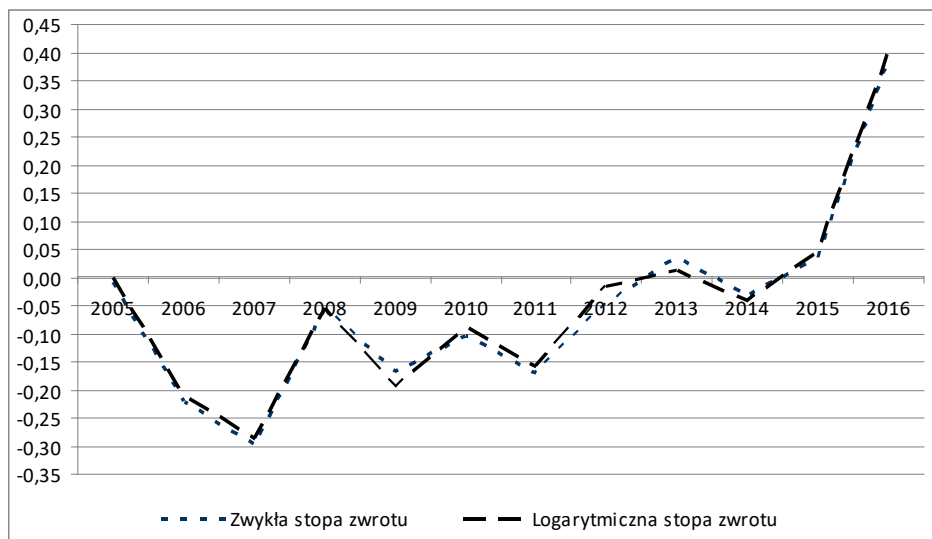
Oznacza to, że dla rynku polskiego najważniejszymi indeksami, które najsilniej oddziaływały na stopy zwrotu indeksu WIG20, były najbardziej popularne indeksy DJIA i S&P500 oraz w mniejszym stopniu indeksy szerokiego rynku Russell 3000 i Wilshire 5000. Analiza $\hat{\beta}$ co do wartości bezwzględnych oszacowań tego parametru prowadzi do wniosku, że największy wpływ wśród wszystkich indeksów z rynku w USA wywierał DJIA. Rezultat ten jest zgodny z wynikami z artykułu J. Brzeszczyńskiego i A. Welfego (2007), otrzymanymi na podstawie wcześniejszej próby statystycznej, obejmującej lata 1998–2002.

Ważnym wnioskiem wynikającym z tabel 1, 2 oraz 3 jest także powtarzający się systematycznie brak istotności statystycznej oszacowań parametru β w każdym przypadku w drugiej podpróbie, co świadczy o osłabieniu badanej zależności wraz z upływem czasu.

Efekt ten w dalszej kolejności został przeanalizowany bardziej szczegółowo w całym okresie 12 lat – od roku 2005 do roku 2016 – w ujęciu rocznym na przykładzie modelu ze stopami zwrotu indeksu DJIA jako zmienną objaśniającą. W tym celu wykonane zostały dodatkowe estymacje parametru β w podpróbach o długości jednego roku (dla modeli ze zwykłą stopą zwrotu oraz dla porównania także dla modeli z logarytmiczną stopą zwrotu), co pozwoliło sprawdzić, jak przebiegała ewolucja wartości $\hat{\beta}$ w czasie. Zjawisko to ilustruje rysunek 1.

Rysunek 1 przedstawia wartości oszacowań parametru β w 12 podpróbach o długości jednego roku w latach 2005–2016. Na przestrzeni całego tego okresu ewidentnie widać jego ewolucję od wartości ujemnych, osiagających poziom $-0,3$ w roku 2007, do wartości dodatniej, sięgającej poziomu $0,4$ w roku 2016. Oznacza to, że badana zależność zmieniła znak i w sensie jakościowym jej kierunek odwrócił się pod koniec analizowanej próby.

Wiedza na temat schematu kształtowania się zmienności w czasie oszacowań parametru β jest szczególnie ważna z punktu widzenia dalszego wykorzystania rezultatów estymacji z okresu próby do prognozowania oraz budowy strategii inwestycyjnych. Jeśli bowiem predykcja stóp zwrotu indeksu WIG20 odbywałaby się wyłącznie na podstawie jednego oszacowania parametru β z całej próby danych historycznych z lat 2005–2016, wówczas proces decyzyjny uzależniony byłby od oszacowania o ujemnym znaku i wartości $-0,059656^{**}$ (jak wskazuje wartość $\hat{\beta}$ dla modelu z indeksem DJIA w tabeli 1). Byłby to jednak błąd, który w dalszej kolejności prowadziłby do decyzji o zakładaniu pozycji przeciwnych niż te, które należałoby otworzyć na rynku na indeksie WIG20 posiadając wiedzę o odwróceniu zależności w drugiej części próby i przejściu oszacowań parametru β od wartości ujemnych do dodatnich.




Rysunek 1. Przebieg ewolucji oszacowań parametru β z modelu (3a)–(3c) w podpróbach o długości jednego roku w okresie 12 lat (od 2005 do 2016) dla modelu stóp zwrotu indeksu WIG20 z opóźnionymi stopami zwrotu indeksu DJIA jako zmienną objaśniającą (w dwóch wariantach: dla modeli ze zwykłą stopą zwrotu oraz dla modeli z logarytmiczną stopą zwrotu)

Źródło: obliczenia własne


W ostatnim etapie badania wykonany został eksperyment prognostyczny dla modelu stóp zwrotu indeksu WIG20 ze stopami zwrotu indeksu DJIA jako zmienną objaśniającą w oparciu o zaobserwowaną tendencję ewolucji $\hat{\beta}$ w czasie oraz, w szczególności, o wynik estymacji z ostatniego roku (tzn. z roku 2016), czyli dodatnią wartość oszacowanego parametru β . Posłużyła ona do wyznaczenia prognoz w okresie poza próbą w pierwszych trzech miesiącach roku 2017 według reguły mówiącej, że przewidywany kierunek stopy zwrotu indeksu WIG20 zależy od znaku stopy zwrotu indeksu sygnalizującego DJIA.

Ze względu na praktyczny aspekt realizacji tego rodzaju strategii na indeksach giełdowych (wspomniany wcześniej w artykule) dokonano symulacji tej samej zasady inwestycyjnej również na kontrakcie futures na indeks WIG20.




Rysunek 2a. Wynik strategii inwestycyjnej dla indeksu WIG20 w okresie prognostycznym o długości trzech miesięcy poza próbą (2.01.2017–31.03.2017)

Źródło: obliczenia własne




Rysunek 2b. Wynik poszczególnych dziennych transakcji w strategii inwestycyjnej dla indeksu WIG20 w okresie prognostycznym o długości trzech miesięcy poza próbą (2.01.2017–31.03.2017)

Źródło: obliczenia własne



Rysunek 3a. Wynik strategii inwestycyjnej dla kontraktów futures na indeks WIG20 w okresie prognostycznym o długości trzech miesięcy poza próbą (2.01.2017–31.03.2017)

Źródło: obliczenia własne



Rysunek 3b. Wynik poszczególnych dziennych transakcji w strategii inwestycyjnej dla kontraktów futures na indeks WIG20 w okresie prognostycznym o długości trzech miesięcy poza próbą (2.01.2017–31.03.2017)

Źródło: obliczenia własne

W obliczeniach dokonano założenia, że każda pozycja danego dnia otwierana jest według wartości otwarcia indeksu WIG20 lub kontraktu futures na WIG20, a zamykana jest według wartości zamknięcia tego samego dnia dla tych dwóch instrumentów.

Wyniki strategii dla indeksu WIG20 oraz dla kontraktów futures na indeks WIG20 ilustrują rysunki 2a, 2b oraz 3a i 3b. Pokazują one, że dodatnia stopa zwrotu została osiągnięta w obydwóch przypadkach, przy czym jej wartość byłaby wyższa dla indeksu WIG20⁹.

Tabela 4. Stopy zwrotu oraz wartości wskaźnika Sharpe'a w okresie prognostycznym w horyzontach jednego, dwóch oraz trzech miesięcy (w okresie 2.01.2017–31.03.2017)

	Horyzont prognozy		
	1 miesiąc (2.01.2017–31.01.2017)	2 miesiące (2.01.2017–28.02.2017)	3 miesiące (2.01.2017–31.03.2017)
Stopy zwrotu			
Indeks WIG20	4,81%	12,92%	14,82%
Futures na WIG20 (wynik bez dźwigni)	2,98%	9,03%	9,11%
Futures na WIG20 (wynik z dźwignią)	28,52%	115,88%	97,92%
Odchylenie standardowe stóp zwrotu			
Indeks WIG20	0,88%	0,82%	0,90%
Futures na WIG20 (wynik bez dźwigni)	0,70%	0,73%	0,81%
Futures na WIG20 (wynik z dźwignią)	7,02%	7,25%	8,10%
Wskaźnik Sharpe'a			
Indeks WIG20	5,47	15,85	16,52
Futures na WIG20 (wynik bez dźwigni)	4,24	12,44	11,24
Futures na WIG20 (wynik z dźwignią)	4,06	15,97	12,08

Źródło: obliczenia własne

Obraz ten zmienia się jednak w przypadku wprowadzenia korekty uwzględniającej ryzyko. Tabela 4 prezentuje stopy zwrotu w całym okresie prognostycznym w horyzontach jednego, dwóch oraz trzech miesięcy i wartości odchylenia standardowego stóp zwrotu oraz wskaźnika Sharpe'a dla indeksu WIG20 oraz dla kontraktów futures na WIG20 w wariancie z dźwignią finansową (x 10) dla rzeczywistej inwestycji w kontrakt futures oraz, dla porównania, w wariancie bez dźwigni finansowej (dla bezpośredniego porównania z samym indeksem WIG20). Z analizy tych rezultatów wynika, że cena kontraktu futures na indeks WIG20 charakteryzowała się z reguły niższą zmiennością niż indeks WIG20. W oczywi-

⁹ Warto zauważyć, że w przypadku tego rodzaju strategii, wykorzystującej kontrakty futures, wyniki zależeć będą także od dźwigni finansowej, która występuje przy inwestycjach w instrumenty pochodne. Dla kontraktów futures na indeks WIG20 mnożnik dźwigni finansowej wynosi 10.

sty sposób prowadzi to do proporcjonalnie mniejszych różnic między tymi dwoma instrumentami, gdy ocena odbywa się na podstawie wskaźnika Sharpe'a.

Na koniec należy jeszcze wspomnieć o wpływie kosztów transakcyjnych, które – jeśli zostałyby uwzględnione w obydwóch strategiach – zmieniłyby zasadniczo ich ostateczny wynik. Przyjmując typową wartość prowizji za transakcję na kontrakcie futures na indeks WIG20 w granicach 7–9 zł (w zależności od biura maklerskiego i platformy transakcyjnej) oraz około 0,2–0,4% prowizji za zakup i sprzedaż wszystkich akcji z portfela WIG20, strategia realizowana na kontraktach futures cały czas pozostałaby zyskowna w analizowanym okresie prognozytycznym, natomiast w przypadku indeksu WIG20 dodanie kosztów transakcyjnych doprowadziłoby do ujemnej stopy zwrotu, czyli do straty.

Sytuacja ta ilustruje znaczenie kontraktów futures w tego typu strategiach inwestycyjnych, które ze względu na znacząco niższe koszty transakcyjne stanowią lepszy instrument do wykorzystywania w praktyce przez inwestorów niż bezpośredni zakup oraz sprzedaż akcji z indeksu.

6. Podsumowanie

Modele ekonometryczne, umożliwiające opis oraz prognozowanie procesów transmisji sygnałów między giełdami akcji na świecie, zajmują ważne miejsce w literaturze z zakresu finansów oraz posiadają duże znaczenie praktyczne, gdyż mogą zostać bezpośrednio zastosowane do budowy strategii inwestycyjnych na rynkach akcji.

W obrębie tej metodologii szczególną rolę odgrywają modele typu „Meteor Shower”, które uwzględniają specyficzne rodzaje interakcji zachodzących między rynkami zlokalizowanymi w określonych sekwencjach geograficzno-czasowych, wyznaczonych przez okresy ich aktywności giełdowej.

Ważnym zagadnieniem badawczym, mającym szczególne znaczenie praktyczne, jest wiedza na temat możliwej ewolucji zmian wartości szacowanych parametrów w czasie, co ilustruje zaprezentowane w tym artykule badanie empiryczne dla polskiego rynku akcji, na przykładzie stóp zwrotu indeksu WIG20.

Ze względu na występujące w rzeczywistości koszty transakcyjne, innym istotnym aspektem, z praktycznego punktu widzenia, jest wykorzystanie kontraktów futures na indeksy giełdowe zamiast transakcji na poszczególnych składowych akcjach wchodzących w skład badanego i prognozowanego indeksu.

Przyszłe badania dotyczące procesów transmisji sygnałów między giełdami na świecie obejmować powinny także analizy oparte na danych o wyższej częstotliwości niż dzienna, co pozwoli w lepszym stopniu zrozumieć odpowiednie mechanizmy je opisujące oraz ich związki z mikrostrukturą szeroko rozumianego rynku finansowego. Perspektywa taka jest ważna szczególnie dla rynków wscho-

dzących, dla których ciągle występuje relatywnie mało prac na ten temat (potrzeba większego wykorzystania danych o wysokiej częstotliwości wskazana została również jako jedna z istniejących luk poznawczych w literaturze dla rynków wschodzących, m.in. w pracy J. Brzeszczyńskiego, J. Gajdki i A.M. Kutana, 2015).

Bibliografia

- Armitage S., Brzeszczyński J. (2011), *Heteroscedasticity and Interval Effects in Estimating Beta: UK Evidence*, „Applied Financial Economics”, t. 21, s. 1525–1538.
- Baur D.G. (2012), *Financial Contagion and the Real Economy*, „Journal of Banking and Finance”, t. 36, s. 2680–2692.
- Becker K.G., Finnerty J.E., Gupta M. (1990), *The Intertemporal Relation Between the U.S. and Japanese Stock Markets*, „Journal of Finance”, t. 45, s. 1297–1306.
- Beirne J., Gieck J. (2014), *Interdependence and Contagion in Global Asset Markets*, „Review of International Economics”, t. 22, s. 639–659.
- Bekaert G., Ehrmann M., Fratzscher M., Mehl A. (2014), *The Global Crisis and Equity Market Contagion*, „Journal of Finance”, t. 69, s. 2597–2649.
- Bekaert G., Harvey C.R., Ng A. (2005), *Market Integration and Contagion*, „Journal of Business”, t. 78, s. 39–69.
- Bekiros S.D. (2014), *Contagion, Decoupling and the Spillover Effects of the U.S Financial Crisis: Evidence from the BRIC Markets*, „International Review of Financial Analysis”, t. 33, s. 58–69.
- Blatt D., Candelon B., Manner H. (2015), *Detecting Contagion in a Multivariate Time Series System: An Application to Sovereign Bond Markets in Europe*, „Journal of Banking and Finance”, t. 59, s. 1–13.
- Bollerslev T. (1986), *Generalized Autoregressive Conditional Heteroskedasticity*, „Journal of Econometrics”, t. 31, s. 307–332.
- Brzeszczyński J., Gajdka J., Kutana A.M. (2015), *Investor Response to Public News, Sentiment and Institutional Trading in Emerging Markets: A Review*, „International Review of Economics and Finance”, t. 40, s. 338–352.
- Brzeszczyński J., Gajdka J., Schabek T. (2009), *Koniunktura giełdowa a zmiany w realnej sferze gospodarki w Polsce*, „Przegląd Organizacji”, t. 7–8, s. 3–9.
- Brzeszczyński J., Melvin M. (2006), *Explaining Trading Volume in the Euro*, „International Journal of Finance and Economics”, t. 11, s. 24–34.
- Brzeszczyński J., Welfe A. (2007), *Are there Benefits from Trading Strategy Based on the Returns Spillovers to the Emerging Stock Markets? Evidence from Poland*, „Emerging Markets Finance and Trade”, t. 43, s. 74–92.
- Campbell J.Y., Grossman S.J., Wang J. (1993), *Trading Volume and Serial Correlation in Stock Returns*, „Quarterly Journal of Economics”, t. 108, s. 905–939.
- Cho S., Hyde S., Nguyen N. (2015), *Time-varying Regional and Global Integration and Contagion: Evidence from Style Portfolios*, „International Review of Financial Analysis”, t. 42, s. 109–131.
- Chordia T., Roll R., Subrahmanyam A. (2001), *Market Liquidity and Trading Activity*, „Journal of Finance”, t. 56, s. 501–530.
- Chordia T., Sarkar A., Subrahmanyam A. (2005), *An Empirical Analysis of Stock and Bond Market Liquidity*, „Review of Financial Studies”, t. 18, s. 85–129.
- Connolly R.A., Wang F.A. (2003), *International Equity Market Comovements: Economic Fundamentals or Contagion?*, „Pacific-Basin Finance Journal”, t. 11, s. 23–43.
- Dacorogna M.M., Gençay R., Müller U.A., Olsen R.B., Pictet O.V. (2001), *An Introduction to High-Frequency Finance*, Academic Press, San Diego.

- Dacorogna M.M., Müller U.A., Olsen R.B., Pictet O.V. (1998), *Modeling Short-Term Volatility with GARCH and HARARCH Models*, [w:] C. Dunis, B. Zhou (eds.), *Nonlinear Modeling of High Frequency Financial Time Series*, John Wiley, Chichester.
- Dornbusch R., Park Y.C., Claessens S. (2000), *Contagion: Understanding How it Spreads*, „World Bank Research. Observer”, t. 15, s. 177–197.
- Dungey M., Gajurel D. (2014), *Equity Market Contagion During the Global Financial Crisis: Evidence from the World's Eight Largest Economies*, „Economic Systems”, t. 38, s. 161–177.
- Dungey M., Milunovich G., Thorp S., Yang M. (2015), *Endogenous Crisis Dating and Contagion Using Smooth Transition Structural GARCH*, „Journal of Banking and Finance”, t. 58, s. 71–79.
- Engle R.F. (1982), *Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation*, „Econometrica”, t. 50, s. 987–1007.
- Engle R.F., Ito T., Lin W.-L. (1990), *Meteor Showers or Heat Waves? Heteroscedastic Intra-daily Volatility in the Foreign Exchange Market*, „Econometrica”, t. 59, s. 525–542.
- Forbes K.J., Rigobon R. (2002), *No Contagion, Only Interdependence: Measuring Stock Market Comovements*, „Journal of Finance”, t. 57, s. 2223–2261.
- Gagnon L., Karolyi G.A. (2003), *Information, Trading Volume and International Stock Market Comovement*, „International Finance Review”, t. 4., s. 347–377.
- Gagnon L., Karolyi G.A. (2006), *Price and Volatility Transmission Across Borders*, „Financial Markets, Institutions and Instruments”, t. 15, s. 107–158.
- Gagnon L., Karolyi G.A. (2009), *Information, Trading Volume and International Stock Return Comovements: Evidence from Cross-listed Stocks*, „Journal of Financial and Quantitative Analysis”, t. 44, s. 953–986.
- Gębka B. (2012), *The Dynamic Relation Between Returns, Trading Volume and Volatility: Lessons from Spillovers Between Asia and the United States*, „Bulletin of Economic Research”, t. 64, s. 65–90.
- Gębka B., Serwa D. (2006), *Are Financial Spillovers Stable Across Regimes? Evidence from the 1997 Asian Crisis*, „Journal of International Financial Markets, Institution and Money”, t. 16, s. 301–317.
- Gębka B., Serwa D. (2007), *Intra- and Inter-regional Spillovers Between Emerging Capital Markets Around the World*, „Research in International Business and Finance”, t. 21, s. 203–221.
- Gębka B., Serwa D. (2015), *The Elusive Nature of Motives to Trade: Evidence from International Stock Markets*, „International Review of Financial Analysis”, t. 39, s. 147–157.
- Hamao Y., Masulis R., Ng V. (1990), *Correlations in Price Changes and Volatility Across International Stock Markets*, „Review of Financial Studies”, t. 3, s. 281–307.
- Ibrahim B.M., Brzeszczyński J. (2009), *Inter-regional and Region-specific Transmission of International Stock Market Returns: The Role of Foreign Information*, „Journal of International Money and Finance”, t. 28, s. 322–343.
- Ibrahim B.M., Brzeszczyński J. (2014), *How Beneficial Is International Stock Market Information in Domestic Stock Market Trading?*, „European Journal of Finance”, t. 20, s. 201–231.
- Ito T., Engle R.F., Lin W.-L. (1992), *Where Does the Meteor Shower Come From? The Role of Stochastic Policy Coordination*, „Journal of International Economics”, t. 32, s. 221–240.
- Karolyi A.G. (2003), *Does International Finance Contagion Really Exist?*, „International Finance”, t. 6, s. 179–199.
- Kenourgios D., Dimitriou D. (2015), *Contagion of the Global Financial Crisis and the Real Economy: A Regional Analysis*, „Economic Modelling”, t. 44, s. 283–293.
- King M.A., Wadhvani S. (1990), *Transmission of Volatility between Stock Markets*, „Review of Financial Studies”, t. 3, s. 5–33.
- Lane P.R., Milesi-Ferretti G.M. (2017), *International Financial Integration in the Aftermath of the Global Financial Crisis*, IMF Working Paper No. WP/17/115.



- Lau C.K.M., Vigne S.A., Wang S., Yarovaya L. (2017), *Return Spillovers Between White Precious Metal ETFs: The Role of Oil, Gold, and Global Equity*, „International Review of Financial Analysis”, t. 52, s. 316–332.
- Lekonen H. (2015), *Stock Market Integration and the Global Financial Crisis*, „Review of Finance”, t. 19, s. 2039–2094.
- Lin W.-L., Engle R.F., Ito T. (1994), *Do Bulls and Bears Move across Borders? International Transmission of Stock Returns and Volatility*, „Review of Financial Studies”, t. 7, s. 507–538.
- Longin F., Solnik B. (2001), *Extreme Correlation of International Equity Markets*, „Journal of Finance”, t. 56, s. 649–676.
- Luchtenberg K., Vu Q.V. (2015), *The 2008 Financial Crisis: Stock Market Contagion and Its Determinants*, „Research in International Business and Finance”, t. 33, s. 178–203.
- Melvin M., Peiers Melvin B. (2003), *The Global Transmission of Volatility in the Foreign Exchange Market*, „Review of Economics and Statistics”, t. 85, s. 670–679.
- Pesaran M.H., Timmermann A. (1992), *A Simple Nonparametric Test of Predictive Performance*, „Journal of Business and Economic Statistics”, t. 10, s. 461–465.
- Sheng X., Brzeszczyński J., Ibrahim B.M. (2017), *International Stock Return Co-movements and Trading Activity*, „Finance Research Letters”, t. 23, s. 12–18.
- Yarovaya L., Brzeszczyński J., Lau C.K.M. (2016a), *Intra- and Inter-regional Return and Volatility Spillovers across Emerging and Developed Markets: Evidence from Stock Indices and Stock Index Futures*, „International Review of Financial Analysis”, t. 43, s. 96–114.
- Yarovaya L., Brzeszczyński J., Lau C.K.M. (2016b), *Volatility Spillovers across Stock Index Futures in Asian Markets: Evidence from Range Volatility Estimators*, „Finance Research Letters”, t. 17, s. 158–166.

Modelling and Forecasting of Signal Transmission Processes among Stock Markets

Abstract: Signal transmission processes among international financial markets, at the level of both price volatility and returns direction, are complex phenomena, in particular in case of the application of high frequency data. This paper presents models describing such effects, discussion of selected methodological issues, empirical application for the Polish market and also indicates the possibilities for using such tools for the construction of investment strategies on the stock markets. Empirical study for the WIG20 index conducted on the sample of years 2005–2016 demonstrates the existence of the relationship between the variability of the WIG20 index returns and the returns of the indices from the US market, whereas the strongest dependence has been identified in case of the DJIA index. Moreover, an evolution effect of the value of the estimated parameters over time has been detected. The estimates from the in-sample period from years 2005–2016 were further exploited in the out-of-sample experiment using the data from the year 2017 with additional application of index futures contracts on the WIG20 index.

Keywords: stock market, stock indices, futures contracts on stock indices, information transmission processes among stock markets

JEL: C32, G15, G17

 <p>OPEN  ACCESS</p>	<p>© by the author, licensee Łódź University – Łódź University Press, Łódź, Poland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution license CC-BY (http://creativecommons.org/licenses/by/3.0/)</p>
	<p>Received: 2017-08-20; verified: 2018-02-20. Accepted: 2018-11-26</p>